PATENT ABSTRACTS OF JAPAN

(11)Publication number : 06-289179
(43)Date of publication of application : 18.10.1994

---

(51)Int.Cl.
G21C 17/00
G01D 21/00
G21C 17/02
// G05B 23/00

---

(21)Application number : 05-095465
(22)Date of filing : 30.03.1993
(71)Applicant : HITACHI LTD
(72)Inventor : NAGASE MAKOTO
FUJIMORI HARUO
YAMADA IZUMI
UCHIDA SHUNSUKE
ARITA SETSUO
FUKUZAKI KOJI
TAKAHASHI FUMINOBU

---

(54) SELF LEARNING DIAGNOSIS FOR PLANT, ESTIMATION AND DEVICE THEREFOR

(57)Abstract:

PURPOSE: To permit the self repairing of parameter and improve the estimation precision by optimizing the model parameter from the measured value of a plant and the corresponding analytical value and carrying out self learning.

CONSTITUTION: After the simulation using the initial input based on the plant design is executed, the operation parameter 10 and the state quantity 11 measured for a restricted period are read in 2, and the analytical value through the simulation and the state quantity 11 are compared, and the existence of annmaly is judged 6. When no anomaly exists and the number of data of the state quantity 11 exceeds a prescribed value, the model parameter is automatically optimized 3 so that the differential square sum between the data value and the corresponding analytical value becomes min. After the optimization, the correlation between the left difference and the whole state quantity 11 is analyzed 4, and the state quantity 11 in the strong correlation is added to the variable for the newly calculation of model parameter, and self learning 5 is performed. When anomaly is detected, the cause of the anomaly is identified on the basis of the difference between the estimated value which is calculated beforehand and the state quantity 11, and the constitution equipment, life of material, or the cumulative quantity of the radioactive is estimated 7 from the model parameter value in optimization.

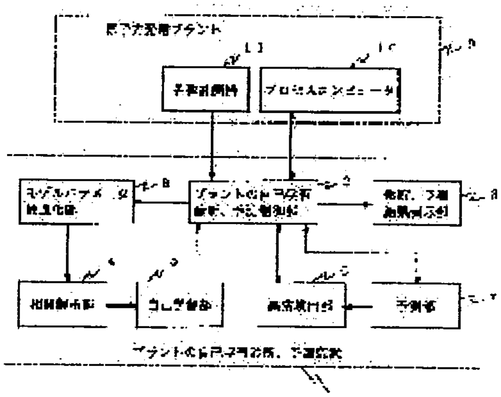

Reference 2

Patent Application Public-disclosure No.: 289179/1994 (H06-289179)
Publication date: October 18, 1994
Patent application No.: 95465/1993 (H05-95463)
Patent application date: March 30, 1993
Inventor: Makoto Nagase et al.
Applicant: Hitachi, Ltd.
Title of the invention: Method and Apparatus for Self Learning Diagnosis and Prediction in a Plant

< Partial translation >

— — — — —

- - - - - In the above variables, C, C_f, F_f, R and Γ_2 are quantities of states (hereinafter, state quantities) measurable during operation of a reactor plant; M, A, Γ_1 are state quantities of structures (a fuel rod, etc.) which can be measured when the structures are taken out of a reactor while it is stopped for a periodic inspection; V, S_1 and S_2 are plant parameters which are specific to the plant; λ, G and G_1 are physical constants which are determined according to types of nucleuses in radioactive corrosion products; and X, Y, ζ, ζ_p^1, ζ_p^2, δ, δ_p^1, δ_p^2 and β are model parameters in principle. Note that, since it is difficult to distinguish m_1 and m_2 (amounts of corrosion products) (because it is difficult to determine whether corrosion products are adhered from water-side, or produced by corrosion of a structure material), they are quantities which are difficult to measure.

[0008]

A procedure for self-learning diagnosis and a prediction method will be explained with reference to Fig. 4. At the beginning, based on plant design parameters, plant parameters V, S_1 and S_2, physical constants λ, G and G_1, and model parameters X, Y, ζ, ζ_p^1, ζ_p^2, δ, δ_p^1, δ_p^2 and β are set to be initial input data for simulation. Next, the simulation is carried out by use of the initial input data. Initial setting is completed upon completion of the simulation, and a process for collecting data from the operating plant and a process for diagnosing the plant are initiated. First, the operation parameters such as an output and an amount of feedwater, and measurable state quantities such as concentration of corrosion products in feedwater and reactor water C, C_f, R and radiation accumulated in structure materials out of the reactor Γ_2 are read from the plant. Based on the operation parameters, it is judged whether the plant is in steady operation. During non-steady operation, since it is not possible to carry out diagnosis until accuracy of the simulation model is increased to a predetermined level, the procedure returns to the collection process for collecting next data. During steady operation, judgment for determining whether an abnormality exists is carried out by comparison of analyzed values and measurable state quantities. In the case that an abnormality does not exist, if the number of pieces of data, each of which represents a measurable state quantity, exceeds 5, the procedure enters self-optimization process of model parameters. If the number of pieces of data is insufficient for the process (for example, less than 5), the procedure returns to the data collection process. In this example, actual measured values of state quantities during an abnormal state and a transitional operation state of the plant are excluded. Next, if the sum of squares of the analyzed value and actual measured value which are obtained after completion of the model parameters self-optimization process exceeds a predetermined threshold value, the procedure enters a process for self-learning of a model. If the obtained value is smaller than the threshold value or when the self-learning process is completed, the procedure returns to the data collection process. On the other hand, when an abnormality is detected/confirmed, the procedure enters a process for diagnosing the abnormality and predicting events/effects caused by the abnormality. Upon completion of the process, the procedure returns to the data collecting process. The model parameters self-optimization process, the model self-learning process, and the abnormality diagnosing process are carried out periodically or when needed. Also, for the measurable state quantities used for self-optimization of model parameters, state quantities measured during a defined period are used.

[0009]

A procedure for diagnosing an abnormality and predicting events/effects caused by the abnormality will be explained with reference to Fig. 5. A measured state quantity and a predicted analyzed value are compared and, if a result of the comparison exceeds a predetermined threshold value, the procedure enters an abnormality diagnosis process. In the abnormality diagnosis process, first, a deviation pattern is generated based on the measured state quantity and the predicted analyzed value. In the deviation pattern of an example shown in Fig. 15 (Table 1), values of ratios of the analyzed values and actual measured values for one state quantity are classified into six symbols (++, +, -, --, +-, 0). Symbol patterns corresponding to the number of state quantities to be measured are made. In Fig. 15, "++" represents a value of "ratio > 2" (the ratio is greater than 2), "+" represents "2 ≥ ratio > 1.5", "-" represents "0.67 > ratio ≥ 0.5", "--" represents "0.5 > ratio", "+-" represents

"0 > ratio", and "0" represents "$1.5 \geq$ ratio ≥ 0.67". Note that the ratios and the number of classes in classification other than this example can be used. An example of a deviation pattern when detecting an abnormality is shown in Fig. 16 (Table 2). In this example, ten measurable state quantities in water in the reactor are considered; that is, Fe, Ni, Co, Cr and Na, and radioactive products ^{54}Mn, ^{58}Co, ^{50}Co, ^{51}Cr and ^{24}Na. After the deviation pattern is made, "a change pattern" at the time that the model parameter changes and "the deviation pattern" are compared, for selecting a model parameter which has the highest degree of coincidence. Fig. 17 (Table 3) shows an example of a change pattern. A definition of the change pattern is shown in Fig. 18 (Table 4). The model parameter in Fig. 17 which coincides with the example shown in Fig. 2 is "increase (in speed) of corrosion of Inconel in a reactor". Next, data indicating the cause of change in the model parameter having the highest degree of coincidence is retrieved from a knowledgebase, which is constructed in advance, and the retrieved data is presented to an operator. In the above example, in response to the data indicating "increase (in speed) corrosion of Inconel in a reactor", data indicating cause "fretting wear of a fuel spacer" is retrieved from the knowledgebase, and the retrieved data is presented to the operator. In this manner, cause of an abnormality is determined. Next, an amount of change of a parameter, which will be appropriate for a newest actual measured value, is derived based on the changed model parameter, and, by carrying out of a simulation using the new parameter value, an event/effect caused by the abnormality in the future is predicted. In the above example, the events/effects caused by the abnormality are an increase in the amount of radioactive nucleuses accumulated in structure materials due to an increase in radioactivity in water in the reactor and, resultantly, increasing of a dose equivalent rate on the surface of equipment of a primary cooling system. As a result of the prediction, if it is predicted that the dose equivalent rate will increase more than 10%, it will be determined that the predicted matter will affect the radiation exposure dose at the time of the next routine inspection. Thus, the event/effect (increasing of the radiation exposure dose) is quantitatively indicated, and guidance for eliminating the cause of abnormality is presented. More specifically, if it is predicted that the amount of wear is large and it adversely affects the condition of the fuel rod, countermeasures, such as lowering output of the reactor or stopping the operation of the reactor and replacing the fuel assembly or the like, are presented. If a problem of radiation exposure only is predicted, countermeasures, such as increasing the strength of shield when carrying out the next inspection or the like, are presented. If an event/effect caused by the abnormality will not be critical, such a prediction is presented, and the procedure for diagnosing an abnormality and predicting events/effects will be terminated.

Translation of Figs. 4, 5, 15, 16, 17 and 18 of Japanese Patent Application Public-disclosure No. 289179/191994 (Reference 1)

[Fig. 4]

(1) Procedure for self learning diagnosis and prediction method

(2) Setting an initial input by using reference model parameters based on plant design parameters, and executing a simulation

(3) Reading plant operation parameters and measurable parameters

(4) Steady operation?

(5) Abnormal?

(6) Diagnosing for cause of an abnormality, and predicting events/effects caused by the abnormality

(7) whether the number of pieces of data, each of which represents a steady condition, is greater than 5; wherein each piece of data represents a quantity of state

(8) Self-optimizing of model parameters

(9) Whether sum of square is large

(10) Self-learning of a model

[Fig. 5]

(1) Procedure of diagnosis

(2) Making a deviation pattern, based on a value representing an actually measured quantity and a value (analyzed value) which is predicted

(3) Based on a result of comparison between "a change pattern" at the time that a model parameter changes and "the deviation pattern", selecting a model parameter which has the highest degree of coincidence

(4) Retrieving data expressing cause of the change of the model parameter (having the highest degree of coincidence) from knowledge base (which has been made in advance), and indicating/showing the data expressing cause of the change to an operator

(5) Carrying out a simulation by using the changed model parameter, and predicting events/effects caused by the change

(6) Whether the events/effects is significant/large

(7) Indicating/showing the predicted events/effects, and displaying a guidance for eliminating the cause of an abnormality

(8) End of the abnormality diagnosis and prediction process

[Fig. 15]

(1) Example of a definition of a deviation pattern (Table 1)(Fig. 15)

(2) Pattern

(3) Note that y_i is an analyzed value of an i-th measurable quantity of state, and v_i is an actual measured value of an i-th measurable quantity of state

[Fig. 16]

(1) Example of a deviation pattern at the time that an abnormality is detected (Table 2)(Fig. 16)

(2) Quantity of state

(3) Pattern

[Fig. 17]

(1) Example of a change pattern (Table 3)(Fig. 17)

(2) Increase of corrosion of stainless steel in a reactor

(3) Quantity of state

(4) Pattern

(5) Increase of corrosion of Inconel in a reactor

(6) Increase of corrosion of stellite in a reactor

(7) Increase of concentration of iron in feedwater

(8) Increase of concentration of nickel in feedwater

(9) Increase of concentration of cobalt in feedwater

(10) Increase of concentration of chrome in feedwater

[Fig. 18]

(1) Example of a definition of change pattern (Table 4)(Fig. 18)

(2) Pattern

(3) Note that Y_i* is a sum of previous analyzed values of the i-th measurable quantities of states

Fig. 4

【図４】

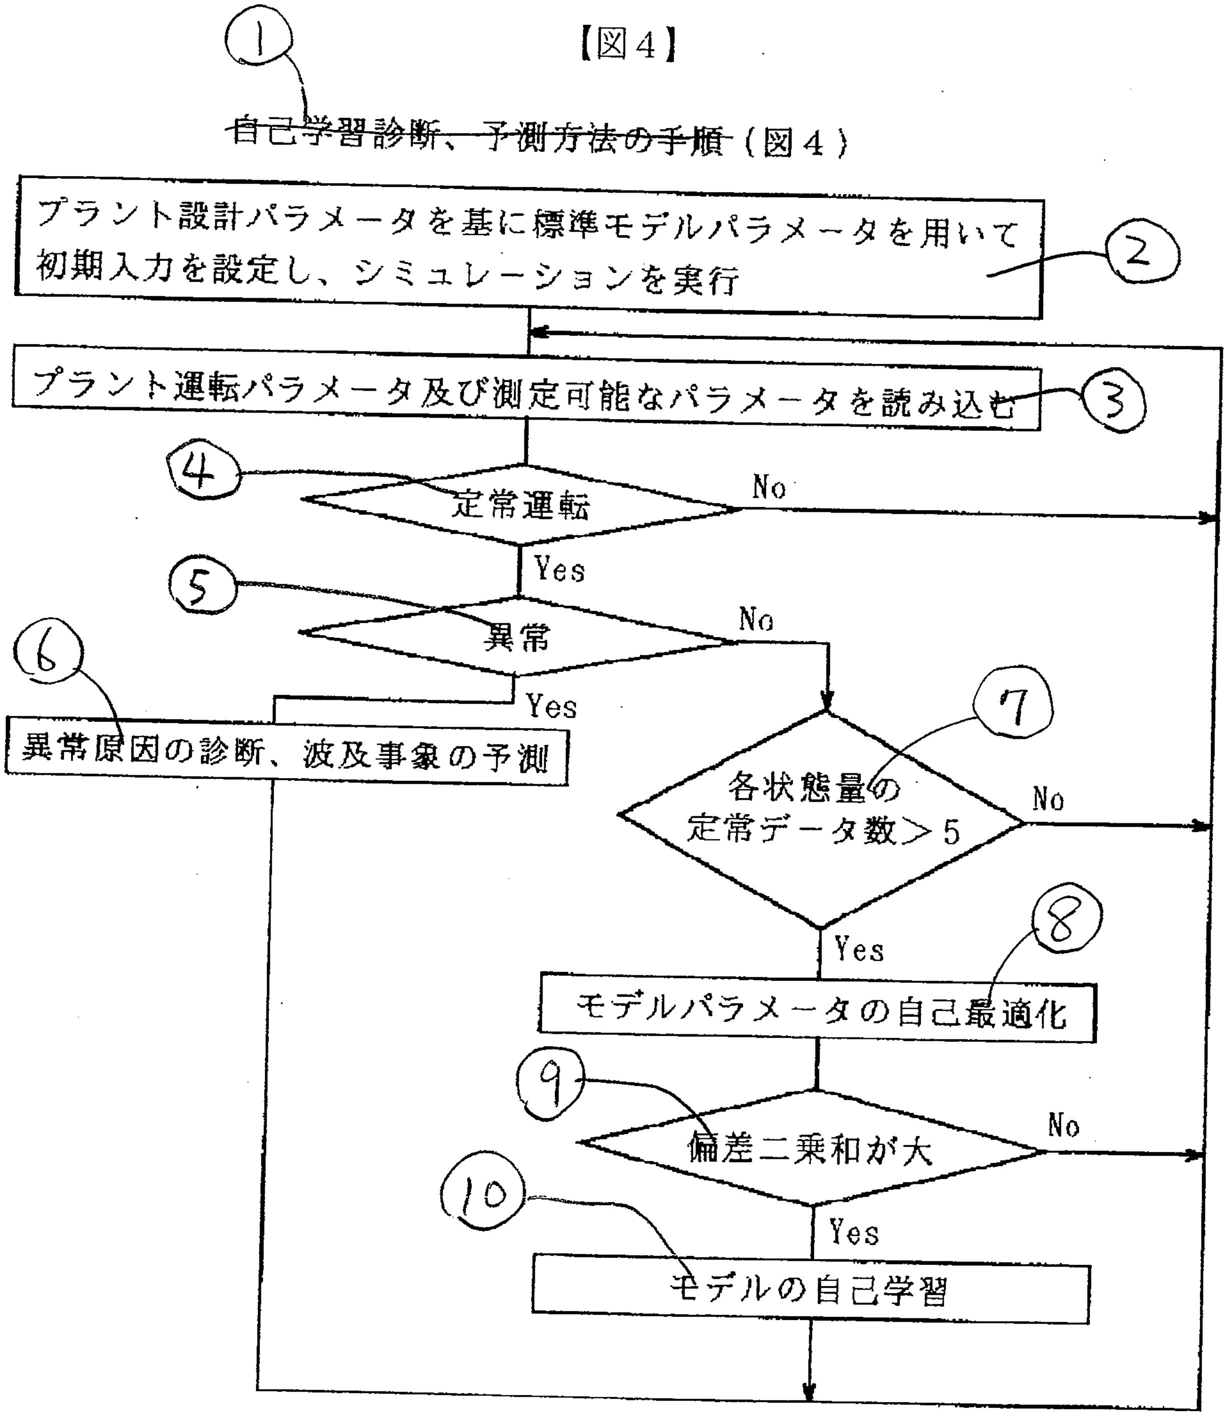
①
~~自己学習診断、予測方法の手順~~（図４）
プラント設計パラメータを基に標準モデルパラメータを用いて初期入力を設定し、シミュレーションを実行
②
プラント運転パラメータ及び測定可能なパラメータを読み込む
③
④
定常運転
No
Yes
⑤
異常
No
Yes
⑥
異常原因の診断、波及事象の予測
⑦
各状態量の定常データ数＞5
No
Yes
⑧
モデルパラメータの自己最適化
⑨
偏差二乗和が大
No
Yes
⑩
モデルの自己学習

Fig. 5

【図５】

① ~~診断の手順~~（図５）

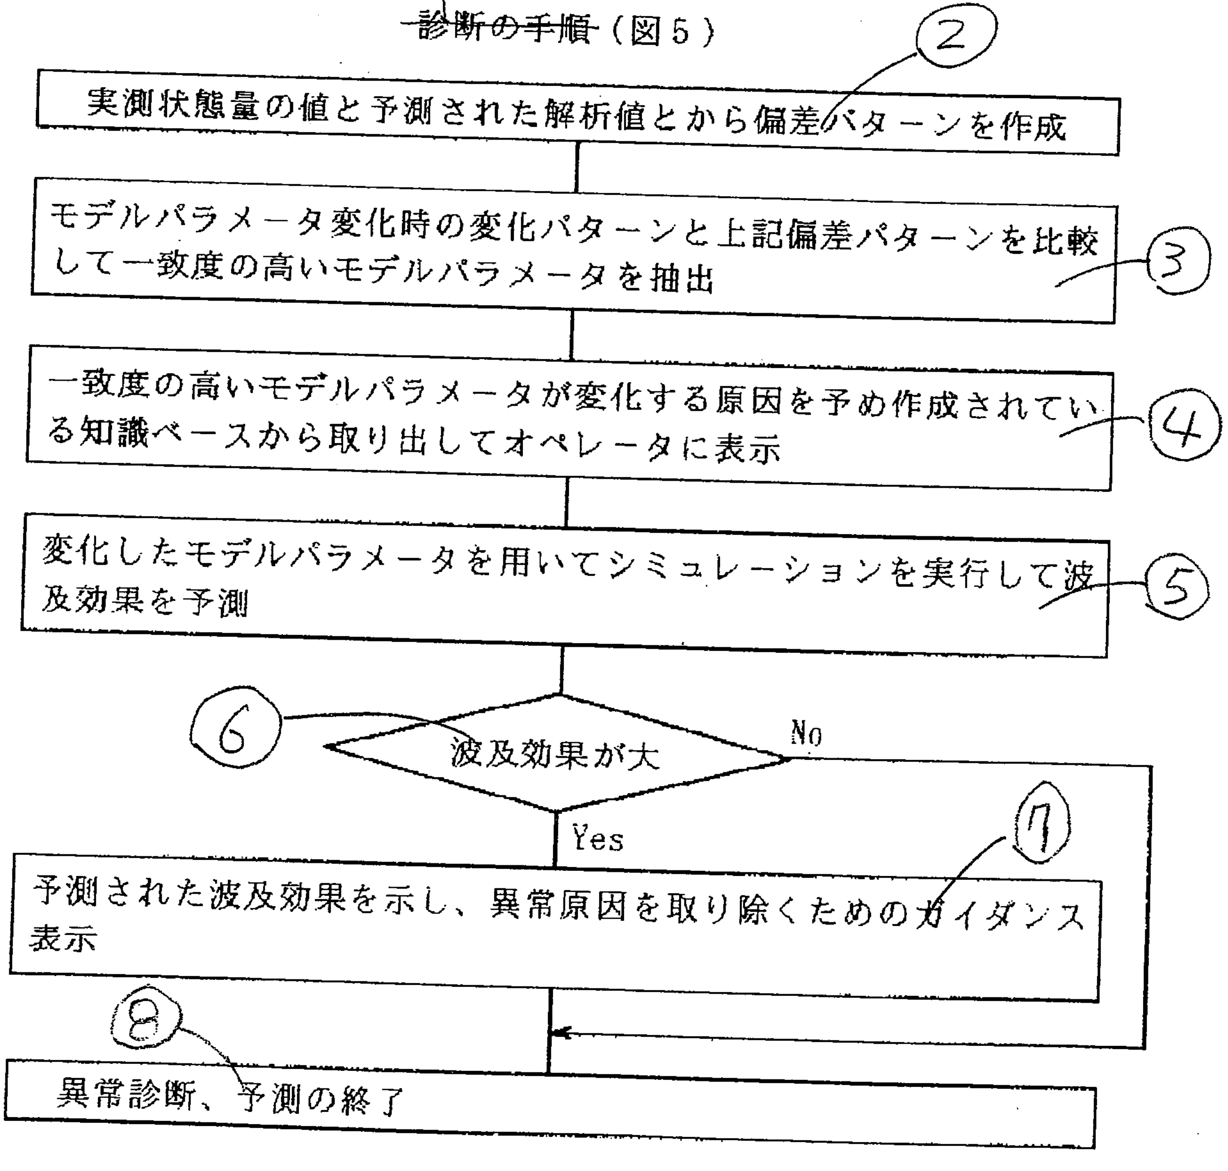
②
実測状態量の値と予測された解析値とから偏差パターンを作成
モデルパラメータ変化時の変化パターンと上記偏差パターンを比較して一致度の高いモデルパラメータを抽出
③
一致度の高いモデルパラメータが変化する原因を予め作成されている知識ベースから取り出してオペレータに表示
④
変化したモデルパラメータを用いてシミュレーションを実行して波及効果を予測
⑤
⑥
波及効果が大
No
Yes
⑦
予測された波及効果を示し、異常原因を取り除くためのガイダンス表示
⑧
異常診断、予測の終了

【図１５】 Fig-15

① ~~偏差パターンの定義例（表１）（図１５）~~

v_i／y_i	＞2	＞1.5	＜0.67	＜0.5	＜0	0.67≦,≦1.5
② パターン	＋＋	＋	−	−−	＋−	0

ただし、y_i は i 番目の測定可能な状態量の解析値

③ v_i は i 番目の測定可能な状態量の実測値

【図１６】 Fig.16

① ~~異常検出時の偏差パターン表の例（表２）（図１６）~~

② 状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
③ パターン	0	＋	0	0	0	0	＋	0	0	0

【図１７】 Fig.17

① ~~変化パターン表の例（表３）（図１７）~~

② ・炉内ステンレス腐食増加

③ 状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
④ パターン	0	0	0	＋	0	0	0	0	＋	0

⑤ ・炉内インコネル腐食増加

③ 状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
④ パターン	0	＋	0	0	0	0	＋	0	0	0

⑥ ・炉内ステライト腐食増加

③ 状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
④ パターン	0	0	＋	0	0	0	0	＋	0	0

⑦ ・給水鉄濃度増加

③ 状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
④ パターン	＋	0	0	0	0	0	0	0	0	0

⑧ ・給水ニッケル濃度増加

③ 状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
④ パターン	0	＋	0	0	0	0	0	0	0	0

⑨ ・給水コバルト濃度増加

③ 状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
④ パターン	0	0	＋	0	0	0	0	0	0	0

⑩ ・給水クロム濃度増加

………………

【図１８】 Fig.18

① ② ~~変化パターンの定義例（表４）（図１８）~~

Y_i／Y_i^*	＞１０	＞２	＜0.5	＜0.1	＜０	0.5≦,≦２
パターン	＋＋	＋	−	−−	＋−	0

③ ただし、Y_i^* は i 番目の測定可能な状態量の前回解析値の総和

(19)日本国特許庁（ＪＰ）　(12) **公開特許公報**（Ａ）　(11)特許出願公開番号

特開平6−289179

(43)公開日　平成６年(1994)10月18日

(51)Int.Cl.⁵	識別記号	庁内整理番号	ＦＩ	技術表示箇所
Ｇ２１Ｃ　17/00				
Ｇ０１Ｄ　21/00	Ｑ	7907−2F		
Ｇ２１Ｃ　17/02				
		8908−2G	Ｇ２１Ｃ　17/ 00	Ｒ
		8908−2G	17/ 02　ＧＤＢ	Ｆ

審査請求　未請求　請求項の数14　ＦＤ　（全 15 頁）　最終頁に続く

(21)出願番号　特願平5−95465

(22)出願日　平成５年(1993)３月30日

(71)出願人　000005108
株式会社日立製作所
東京都千代田区神田駿河台四丁目６番地
(72)発明者　長瀬　誠
茨城県日立市大みか町七丁目２番１号　株式会社日立製作所エネルギー研究所内
(72)発明者　藤森　治男
茨城県日立市大みか町七丁目２番１号　株式会社日立製作所エネルギー研究所内
(72)発明者　山田　泉
茨城県日立市大みか町七丁目２番１号　株式会社日立製作所エネルギー研究所内
(74)代理人　弁理士　笹岡　茂　（外１名）

最終頁に続く

(54)【発明の名称】　プラントの自己学習診断、予測方法及び装置

(57)【要約】

【目的】　プラントの自己学習診断、予測方法において、プラントの仕様、特性等の時間的な変化に対応してモデルパラメータを自動修繕し、予測精度の劣化防止と自己学習による精度の向上を図ることにある。

【構成】　シミュレーションモデルのモデルパラメータを実測された状態量の値と前記実測値に対応する解析値との偏差の二乗和が最小になるように自動的に最適化するステップと、最適化後に残った前記偏差と全ての実測された状態量との相関関係を解析するステップと、相関の強い状態量を新たにモデルパラメータ算出の変数に加えることにより自己学習するステップと、シミュレーションにより事前に算出された状態量の予測値と新たに実測された実測値とを比較して異常の有無を判定するステップと、前記予測値と新たに実測された実測値の偏差に基づき異常原因を同定するステップと、異常原因による波及事象を予測するステップとを備える。

自己学習診断、予測方法の手順（図４）

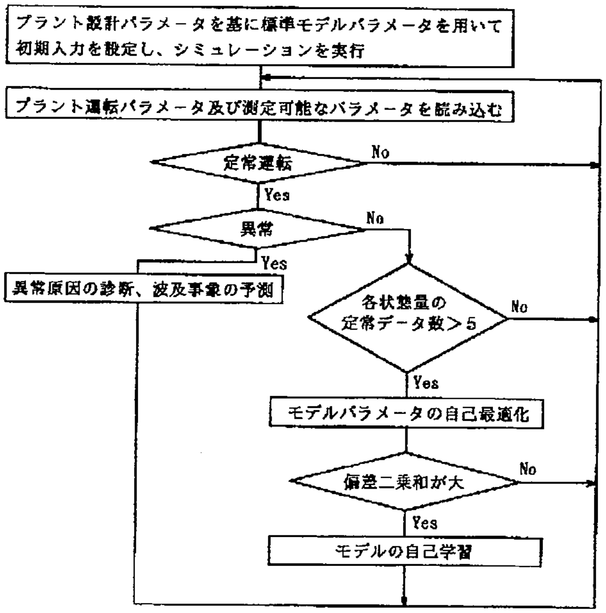
プラント設計パラメータを基に標準モデルパラメータを用いて初期入力を設定し、シミュレーションを実行
プラント運転パラメータ及び測定可能なパラメータを読み込む
定常運転
No
Yes
異常
No
Yes
異常原因の診断、波及事象の予測
各状態量の定常データ数＞５
No
Yes
モデルパラメータの自己最適化
偏差二乗和が大
No
Yes
モデルの自己学習

【特許請求の範囲】

【請求項１】　プラントを循環する冷却系に関わる物理的又は化学的挙動を記述するシミュレーション結果を用いてプラントの構成機器、材料あるいは放射性核種の生成・蓄積の少なくとも１つ以上を対象として診断、予測するプラントの自己学習診断、予測方法において、シミュレーションモデルのモデルパラメータを実測された状態量の値と前記実測値に対応する解析値との偏差の二乗和が最小になるように自動的に最適化するステップと、最適化後に残った前記偏差と全ての実測された状態量との相関関係を解析するステップと、相関の強い状態量を新たにモデルパラメータ算出の変数に加えることにより自己学習するステップと、シミュレーションにより事前に算出された状態量の予測値と新たに実測された実測値とを比較して異常の有無を判定するステップと、前記予測値と新たに実測された実測値との偏差に基づき異常原因を同定するステップと、最適化されたモデルパラメータの値あるいは長期のシミュレーション結果により、構成機器、材料の寿命あるいは放射性核種の蓄積量を予測するステップとを備えたことを特徴とするプラントの自己学習診断、予測方法。

【請求項２】　実測された状態量の値と前記実測値に対応する解析値との偏差の二乗和が最小になるように自動的にモデルパラメータを最適化するステップの前に、プラント異常時の実測値を除いて定常時の実測値を収集するステップを追加することを特徴とする請求項１記載のプラントの自己学習診断、予測方法。

【請求項３】　プラント異常時の実測値に加えて過渡運転時の実測値も除いて、プラント定常時の実測値を所定数以上収集するようにしたことを特徴とする請求項２記載のプラントの自己学習診断、予測方法。

【請求項４】　シミュレーションモデルのモデルパラメータを実測された状態量の値と前記実測値に対応する解析値との偏差の二乗和が最小になるように自動的に最適化するステップとして、プラントデータベースからプラントパラメータを読み込んでシミュレーション入力に変換するステップと、標準モデルパラメータセットをシミュレーション入力に加えるステップと、入力を用いてシミュレーションを実行するステップと、順次入力のモデルパラメータを１つずつ変更してシミュレーションを実行するステップと、変更入力で得られた結果と標準入力による結果とを比較して変化パターンを作成するステップと、偏差パターンと前記変化パターンを比較して偏差が最も小さくなるモデルパラメータを修正するステップと、モデルパラメータの修正によって偏差の縮小を評価するステップと、前記修正プロセスを繰り返した際に偏差が最小になったことを確認するステップから構成されることを特徴とする請求項１から請求項３記載のいずれかのプラントの自己学習診断、予測方法。

【請求項５】　複数プラントにおいて異なるモデルパラ

メータとプラント毎の運転期間中にはほとんど変化しない実測された状態量との相関解析を実施するステップと、前記相関解析の結果として相関の強い状態量を新たにモデルパラメータ算出の変数に加えることにより自己学習するステップを付加することを特徴とする請求項１から請求項４記載のいずれかのプラントの自己学習診断、予測方法。

【請求項６】　モデルパラメータを最適化する際に用いる実測された状態量は期間を限定して計測することを特徴とする請求項１から請求項５記載のいずれかのプラントの自己学習診断、予測方法。

【請求項７】　プラントを循環する冷却系に関わる物理的又は化学的挙動を記述するシミュレーション結果を用いてプラントの構成機器、材料あるいは放射性核種の生成・蓄積の少なくとも１つ以上を対象として診断、予測するプラントの自己学習診断、予測装置において、シミュレーションモデルのモデルパラメータを実測された状態量の値と前記実測値に対応する解析値との偏差の二乗和が最小になるように自動的に最適化する手段と、最適化後に残った前記偏差と全ての実測された状態量との相関関係を解析する手段と、相関の強い状態量を新たにモデルパラメータ算出の変数に加えることにより自己学習をする手段と、シミュレーションにより事前に算出された状態量の予測値と新たに実測された実測値とを比較して異常の有無を判定する手段と、上記４つの手段を定期的にかつ必要に応じて順次動作させると共に異常検出時には前記予測値と新たに実測された実測値との偏差に基づき異常原因を診断する手段と、最適化されたモデルパラメータの値あるいは長期のシミュレーション結果により、構成機器、材料の寿命あるいは放射性核種の蓄積量を予測する手段と、予測結果を表示する手段とを備えたことを特徴とするプラントの自己学習診断、予測装置。

【請求項８】　実測された状態量の値と前記実測値に対応する解析値との偏差の二乗和が最小になるように自動的にモデルパラメータを最適化する前処理として、プラント異常時の実測値を除いて定常時の実測値を収集する手段を有することを特徴とする請求項７記載のプラントの自己学習診断、予測装置。

【請求項９】　プラント異常時の実測値に加えて過渡運転時の実測値も除いて、プラント定常時の実測値を所定数以上収集することを特徴とする請求項８記載のプラントの自己学習診断、予測装置。

【請求項１０】　シミュレーションモデルのモデルパラメータを実測された状態量の値と前記実測値に対応する解析値との偏差の二乗和が最小になるように自動的に最適化する手段として、プラントデータベースからプラントパラメータを読み込んでシミュレーション入力に変換する手段と、標準モデルパラメータセットをシミュレーション入力に加える手段と、入力を用いてシミュレーションを実行する手段と、順次入力のモデルパラメータを

１つずつ変更してシミュレーションを実行する手段と、変更入力で得られた結果と標準入力による結果とを比較して変化パターンを作成する手段と、偏差パターンと前記変化パターンを比較して偏差が最も小さくなるモデルパラメータを修正する手段と、モデルパラメータの修正によって偏差の変化を評価する手段と、前記修正プロセスを繰り返した際に偏差が最小になったことを確認する手段を用いることを特徴とする請求項７から請求項９記載のいずれかのプラントの自己学習診断、予測装置。

【請求項１１】　複数プラントにおいて異なるモデルパラメータとプラント毎の運転期間中にはほとんど変化しない実測された状態量との相関解析を実施する手段と、前記相関解析の結果として相関の強い物理パラメータを新たにモデルパラメータ算出の変数に加えることにより自己学習をする手段とを付加することを特徴とする請求項７から請求項１０記載のいずれかのプラントの自己学習診断、予測装置。

【請求項１２】　シミュレーションを子プロセスとして実行させることを特徴とする請求項７から請求項１１記載のいずれかのプラントの自己学習診断、予測装置。

【請求項１３】　シミュレーションをプラントの自己学習診断、予測用の処理装置とは別の処理装置上で実行させることを特徴とする請求項７から請求項１２記載のいずれかのプラントの自己学習診断、予測装置。

【請求項１４】　シミュレーションを特に２つ以上の複数の別々の処理装置上で同時並列的に実行させることを特徴とする請求項１３記載のプラントの自己学習診断、予測装置。

【発明の詳細な説明】

【０００１】

【産業上の利用分野】本発明は、プラント内を循環する冷却材と冷却材に接する機器・構造材料に生じる異常を検出し、その原因を診断すると共に将来の変化を予測して余寿命を評価するプラントの診断、予測方法及び装置に係わり、特に、物理的又は化学的シミュレーションモデルを自己学習により修繕しながら、解析結果を用いて異常診断と予測を行なうプラントの自己学習診断、予測方法及び装置に関する。

【０００２】

【従来の技術】従来のシミュレーションモデルを利用したプラント診断システムとして、特願昭６２－２２０１７６号に記載されているように、原子炉一次冷却系の線量率を低減するための水質診断システムがある。この水質診断システムでは、現在の水質条件を入力として冷却水中の放射能変化を推定するモデルを用いて、将来のプラント線量率の予測し、その結果に基づき現在の水質条件の良否を診断するものである。

【０００３】

【発明が解決しようとする課題】上記従来技術は、現在測定されている水質条件を入力として、放射性腐食生成

物の挙動を記述するシミュレーションモデルを用い、次の定期検査のための停止時まで、あるいはプラント寿命末期までの長期の予測を行ない、その結果に基づきプラント線量率を低く維持するという観点から、現在の水質状態の良否を診断可能としている。しかしながら、上記従来技術では、シミュレーションモデル及びモデルパラメータは既に存在し、かつ最適化されている必要がある。ところが現実には、同じプラントにおいても運転が継続されていくに従って、機器、材料の交換等に伴ってモデル計算値と実測値の差が大きくなってくることがある。即ち、モデルパラメータが時間的に変化することがある。さらに、プラントが異なれば最適なモデルパラメータが異なってくることも多い。また、モデルパラメータの最適化は人の手によってかなり長い時間をかけて行なわれているのが現状である。つまり、従来技術は、シミュレーションモデルの完成度が高く、モデルパラメータが時間的にも変化しない場合には有効であるが、プラントの仕様、特性等が時間的に変化する場合のパラメータの自己修繕という観点に欠けていた。本発明の目的は、上記事情に鑑み、プラントの仕様、特性等の時間的な変化に対応してモデルパラメータを自動修繕し、予測精度の劣化を防ぐと共に、モデルを自己学習により改良する機能を備えたプラントの自己学習診断、予測方法及び装置を提供することにある。

【０００４】

【課題を解決するための手段】上記目的を達成するため、プラントデータベースからプラントパラメータを読み込んでシミュレーション入力に変換する手段と、標準モデルパラメータセットをシミュレーション入力に加える手段と、入力を用いてシミュレーションを実行する手段と、順次入力のモデルパラメータを１つずつ変更してシミュレーションを実行する手段と、変更入力で得られた結果と標準入力による結果とを比較して変化パターンを作成する手段と、偏差パターンと前記変化パターンを比較して偏差が最も小さくなるモデルパラメータを修正する手段と、モデルパラメータの修正によって偏差の変化を評価する手段と、前記修正プロセスを繰り返した際に偏差が最小になったことを確認する手段と、最適化後に残った前記偏差と全ての実測された状態量との相関関係を解析する手段と、相関の強い状態量を新たにモデルパラメータ算出の変数に加えることにより自己学習をする手段と、シミュレーションにより事前に算出された状態量の予測値と新たに実測された実測値とを比較して異常の有無を判定する手段と、上記偏差が最小になったことを確認する手段、上記相関関係を解析する手段、上記自己学習をする手段、上記異常の有無を判定する手段の４つの手段を定期的にかつ必要に応じて順次動作させると共に異常検出時には前記予測値と新たに実測された実測値との偏差に基づき異常原因を診断する手段と、最適化されたモデルパラメータの値あるいは長期のシミュレ

ーション結果により、構成機器、材料の寿命あるいは放射性核種の蓄積量を予測する手段と、予測結果を表示する手段を用いる。

【０００５】

【作用】本発明において、プラントデータベースから診断対象プラントの設計仕様に関わるデータを読み込んで、シミュレーションプログラムで必要な入力データを作成し、標準モデルパラメータと共に解析の入力として設定することは、モデルパラメータの自己修繕とモデルの自己学習による自己改善の前提条件を与えることに相当する。このようにして設定された初期入力を用いてシミュレーションを実行し、解析結果と実測値を比較して差分パターンを作成し、偏差二乗和を算出することは、モデルパラメータ最適化の比較対象条件を設定する処理に相当する。次に、各モデルパラメータを１つずつ順次変化させてシミュレーションを実行して、標準入力に対する解析結果と比較することにより変化パターンを作成し、かつ、実測値に対する偏差二乗和を算出することは各パラメータ変更時の影響を調べるための前処理である。このようにして作成した変化パターンと差分パターンとから、各パラメータを変化させたときの改善度スコアを作成することは、どのパラメータを優先的に変化させることがモデルパラメータの最適化に重要となるかを判断する材料を提供する。改善度スコアの高いパラメータから順にパラメータを変更させ、偏差の二乗和が小さくなるものだけを採択してパラメータを変更することにより、モデルパラメータの最適化が可能となる。また、最適化後に残った前記偏差と全ての実測された状態量との相関関係を解析し、相関の強い状態量を新たにモデルパラメータ算出の変数に加えることは、モデルパラメータの自己学習を実行することになる。また、シミュレーションにより事前に算出された状態量の予測値と新たに実測された実測値とを比較して異常の有無を判定し、異常検出時には前記予測値と新たに実測された実測値との偏差に基づいて異常原因の同定を行ない、最適化された＊モデルパラメータの値あるいは長期のシミュレーション結果により、異常原因による将来の波及事象、つまり構成機器、材料の寿命あるいは放射性核種の蓄積量を予測することが可能となる。

【０００６】

【実施例】以下、本発明の実施例を図面により説明する。図１は、本発明のプラントの自己学習診断、予測装置の構成と、この装置を原子力発電プラントに適用した例を示す。プラントの自己学習診断、予測装置１は、プラントの自己学習診断、予測制御部２、モデルパラメータ最適化部３、相関解析部４、自己学習部５、異常検出部６、予測部７及び診断、予測結果表示部８から構成される。プラントの自己学習診断、予測装置１は、原子力発電プラント９で使用されるプロセスコンピュータ１０から熱出力等の運転データ及び各種の計測機器１１の出力信号を取り込むようにしている。

【０００７】モデルパラメータ最適化部の詳細構成を図２に示す。モデルパラメータ最適化部３は、モデルパラメータ最適化制御部１２、プラントパラメータ設定部１３、標準パラメータ設定部１４、モデルパラメータ収納部１５、解析入力収納部１６、シミュレーション実行部１７、解析結果収納部１８及び変化パターン作成部１９から構成される。各部の具体的な記述を行う前に、シミュレーションモデルの一例として、沸騰水型原子炉一次冷却系における腐食生成物に関するマスバランスモデルについて、簡単に説明する。マスバランスモデルは、図３に示すように、給水中に含まれている腐食生成物と炉水に接する炉内外の構造材の腐食に伴って発生する腐食生成物とが、炉水を介在して燃料棒表面や炉内外の構造材表面に再付着したり、原子炉浄化系によって系外に除去されたりする動的挙動をマクロな質量保存則によって記述するものである。すなわち、腐食生成物のマスバランスは、以下に示す式１から式８のような連立微分方程式群により記述される。

【数１】

$$\frac{dC}{dt}=\frac{1}{V}\{F_f C_f+X+\zeta M+\zeta_p^1 m_1+\zeta_p^2 m_2 -(\delta V+\beta V+\delta_p^i S_1+\delta_p^2 S_2)C\} \quad \cdots\cdots（式１）$$

【数２】

$$\frac{dM}{dt}=\delta CV-\zeta M \quad \cdots\cdots（式２）$$

【数３】

$$\frac{dm_1}{dt}=\delta_p^1 S_i C-\zeta_p^1 m_1 \quad \cdots\cdots（式３）$$

【数４】

$$\frac{dm_2}{dt}=\delta_p^2 S_2 C-\zeta_p^2 m_2 \quad \cdots\cdots（式４）$$

【数５】

$$\frac{dR}{dt}=\frac{1}{V}\{Y+\zeta A+\zeta_p^1\Gamma_1+\zeta_p^2\Gamma_2-(\delta V+\beta V+\delta_p^1 S_1+\delta_p^2 S_2+\lambda)R\} \quad \cdots\cdots(\text{式}5)$$

【数6】

$$\frac{dA}{dt}=GM+\delta RV-(\zeta+\lambda)A \quad \cdots\cdots(\text{式}6)$$

【数7】

$$\frac{d\Gamma_1}{dt}=G_1 m_1+\delta_p^1 S_1 R-(\zeta_p^1+\lambda)A \quad \cdots\cdots(\text{式}7)$$

【数8】

$$\frac{d\Gamma_2}{dt}=\delta_p^2 S_2 R-(\zeta_p^2+\lambda)A \quad \cdots\cdots(\text{式}8)$$

上記式において、Ｃは炉水中の腐食生成物濃度、具体的には鉄、ニッケル、コバルトなどの濃度、C_fは前記腐食生成物の給水中濃度、F_fは給水流量、Ｖは炉水保有水量、Ｘは炉内外構造材の腐食により発生する前記腐食生成物の発生率、Ｍは燃料棒上に蓄積する腐食生成物量、m_1、m_2は炉内外の構造材表面に付着蓄積する腐食生成物量、S_1、S_2は炉内外の構造材の表面積、ζ、ζ_p^1、ζ_p^2はそれぞれ燃料棒及び炉内外構造材付着物の溶出あるいは剥離定数、δ、δ_p^1、δ_p^2はそれぞれ燃料棒及び炉内外構造材への付着定数、βは原子炉浄化系における除去率、ｔは時間、Ｒは放射性腐食生成物濃度、具体的には^{60}Ｃｏ、^{58}Ｃｏ、^{54}Ｍｎなどの濃度、Ｙは炉内構造材の腐食により発生する前記放射性腐食生成物の発生率、Ａは燃料棒上に蓄積する放射性腐食生成物量、Γ_1、Γ_2は炉内外の構造材表面に付着蓄積する放射性腐食生成物量、λは前記放射性腐食生成物の崩壊定数、Ｇ、G_1は燃料棒及び炉内構造材上における放射性核種の生成率をそれぞれ示している。上記変数の内、Ｃ、C_f、F_f、Ｒ、Γ_2は運転中に測定可能な状態量、Ｍ、Ａ、Γ_1は定期検査などの停止時に炉内から取り出したときに測定可能な状態量、Ｖ、S_1、S_2はプラント固有のプラントパラメータ、λ、Ｇ、G_1は放射性腐食生成物の核種に応じて定まる物理定数、Ｘ、Ｙ、ζ、ζ_p^1、ζ_p^2、δ、δ_p^1、δ_p^2、βは原則的にモデルパラメータである。なお、m_1、m_2は水側から付着したものと構造材の腐食によって発生したものとの区別ができないので、通常測定が困難な状態量である。

【０００８】自己学習診断、予測方法の手順を図４を用いて説明する。まず始めに、プラント設計パラメータに基づき、前記プラントパラメータＶ、S_1、S_2、物理パラメータλ、Ｇ、G_1及び予め設定してある標準モデルパラメータＸ、Ｙ、ζ、ζ_p^1、ζ_p^2、δ、δ_p^1、δ_p^2、βをシミュレーションの初期入力として設定する。次に、前記初期入力を用いてシミュレーションを実行する。シミュレーションが終了した時点で初期設定が終了し、運転プラントからのデータの収集と診断が開始される。まず、プラントから運転パラメータである出力や給水流量、及び測定可能な状態量である給水及び炉水の腐食生成物濃度Ｃ、C_f、Ｒと炉外構造材に蓄積した放射能Γ_2を読み込む。運転パラメータから定常運転中か否かを判定し、非定常運転中はシミュレーションモデルの精度が向上するまでは診断不可能なので、次のデータ収集プロセスに戻る。定常運転時には、シミュレーションによる解析値と測定可能な状態量とを比較することにより異常の判定を行なう。異常がない場合は、各測定可能な状態量のデータ数が例えば５より大きくなった時に、モデルパラメータの自己最適化プロセスに入り、データ数が不足する場合はデータ収集プロセスに戻る。ここではプラント異常時及び過渡運転時の状態量の実測値を除く。次に、モデルパラメータの自己最適化プロセス終了後に算出した実測値と解析値との偏差二乗和が予め設定してあるしきい値より大きい時にはモデルの自己学習プロセスに入り、しきい値より小さいとき及び自己学習終了後はデータ収集プロセスに戻る。一方、異常を確認したときは、異常原因の診断と波及事象の予測プロセスに入り、終了後はデータ収集プロセスに戻る。ここで、モデルパラメータの自己最適化プロセス、モデルの自己学習プロセス及び異常診断プロセスは、定期的にかつ必要に応じて順次動作させる。また、モデルパラメータを自己最適化する際に用いる測定可能な状態量は、期間を限定して計測した状態量を用いる。

【０００９】異常診断と波及事象の予測の詳細手順を図５を用いて説明する。測定した状態量と予測されていた解析値とを比較して予め設定してあるしきい値より大きい場合に異常診断プロセスに入るが、異常診断プロセスでは、まず、測定した状態量と予測されていた解析値とから偏差パターンを作成する。偏差パターンは、表１（図１５）に示すように１つの状態量に対応する解析値と実測値の比の値によって、＋＋、＋、－、－－、＋－、０の６通りの記号に分類し、測定している状態量の数に相当する記号のパターンとして作成されるものである。表１では比の値が２より大きいものを＋＋で、１．５より大きく２以下のものを＋で、０．６７より小さく０．５以上のものを－で、０．５より小さいものを－－

で、0より小さいものを＋－で、0．67以上1．5以下のものを0としたが、しきい値や分類数は別のものを使用することもできる。異常検出時の偏差パターンの具体例としては、表2（図16）に示すパターンがある。ここで、測定可能な状態量としては、炉水中のＦｅ、Ｎｉ、Ｃｏ、Ｃｒ、Ｎａ及びその放射化生成物である^{54}Ｍｎ、^{58}Ｃｏ、^{60}Ｃｏ、^{51}Ｃｒ、^{24}Ｎａの10種類の濃度を考えている。次に、偏差パターンを作成した後、モデルパラメータ変化時の変化パターンと前記偏差パターンを比較して一致度の高いモデルパラメータを抽出する。表3（図17）に変化パターンの一例を示す。変化パターンの定義は表4（図18）に示してある。表2の具体例と一致する表3中のモデルパラメータとしては、炉内インコネル材の腐食速度増加である。次に一致度の高いモデルパラメータが変化する原因を予め作成されている知識ベースから取り出してオペレータに表示する。先の例では炉内インコネル材の腐食速度が増加する原因として、知識ベースから燃料スペーサのフレッティング摩耗が原因として取り出され、オペレータに表示される。このようにして異常原因を同定する。次に、変化したモデルパラメータを用いて最新の実測値に合うパラメータの変化量を定め、そのパラメータ値を用いてシミュレーションにより将来（長期）の波及事象を予測する。先の例の波及事象としては、炉水放射能の上昇に伴う構造材に蓄積する放射性核種の量が増大し、一次冷却系機器表面の線量当量率が上昇することである。予測された結果、例えば10％以上の線量当量率の上昇が予測された場合には、次回定期検査時の被曝線量に影響するとして、その影響を定量的に示すと共に、異常原因を取り除くためのガイダンスを表示する。具体的には摩耗率が大きく燃料棒の健全性に影響しそうな場合には出力を低下させるか運転を停止し、燃料集合体を交換する等の対策を、単に被曝上の問題であれば、次回定検での遮蔽強化等の対策を示す。波及事象が小さい場合には、その旨を示して異常診断と予測プロセスを終了する。

【0010】モデルパラメータ最適化の詳細手順を図6を用いて示す。全体の流れで前述したように、まず、モデルパラメータの初期値を設定してシミュレーションを実行する。解析結果に基づき、差分パターン表を作成し、偏差二乗和を算出する。差分パターンの定義例を表5（図19）に示す。差分パターンは偏差パターンと同様なものであるが、測定可能な状態量ごとに解析値の総和Y_iと実測値の総和V_iとの比の値によって表5に示すしきい値でパターンを定める。ここでいう偏差二乗和とは、全ての測定可能な状態量の解析値と実測値の差を実測値で割った値の二乗の値を加えたものである。直接の差の値を用いないのは、状態量ごとに絶対値が異なるので、状態量ごとの重みを均一とするためである。次に、モデルパラメータを全て変化させるためにｋという変数を1として、ｋ番目のモデルパラメータをm倍してシミュレーションを実行し、変化パターン表を作成する。変化パターンの定義は既に表4に示したが、差分パターンと異なるのは実測値が前回解析値となっている点である。ｍの値としては例えば10としてモデルパラメータの感度解析とする。同様にｋ番目のモデルパラメータをｍで割ってシミュレーションを実行し、変化パターン表を作成する。ｋの値を1増やして次のモデルパラメータに対して同様のシミュレーションを行ない、変化パターン表を作成する操作を繰り返す。全てのモデルパラメータに対する感度解析が終了したら、差分パターン表と変化パターン表から各パラメータ変更時の改善度スコアを作成する。改善度スコアとは、表6（図20）に示すように各状態量ごとの差分パターンと変化パターンの組合せごとにスコアを設定しておき、表7（図21）に具体例を示すように各状態量（α_1～α_5が測定可能な状態量を示す。）のスコアを合計した値（表7の11）をいう。このようにして算出した改善度スコアの大きいモデルパラメータから順にパラメータを変更して解析を実行し、偏差二乗和が縮小することを確認して新たに差分パターンを更新する。全ての差分パターンが0となるまで更新された差分パターンに基づき改善度スコアを更新し、スコアの高いモデルパラメータを変更し、偏差二乗和の縮小確認と差分パターン更新の手順を繰り返す。これによってモデルパラメータの自動最適化が可能となる。上述のようにｍとして例えば10を用い、差分パターンや変化パターンのしきい値を表4、表5のように定義した場合は、シミュレーションのフィッティング程度は各状態量の実測値と解析値がファクター2以内で一致することを意味しており、一致度を向上させるには、ｍの値を小さくすると共にしきい値を変化の小さい方向に変更すればよい。ｍの値を最初に大きく、次第に小さくすることは、始めのうちは解析値のオーダーを実測値に近付け、オーダーが一致したところで細かく合わせていくことに対応している。

【0011】モデル自己学習の詳細手順を図7を用いて示す。前記のようにモデルパラメータの最適化を図ると、図8に示すように点線の最適化前解析値が実線の最適化後解析値となり、実測値（○印）と合うようになるが、それでも偏差二乗和の値が設定値より大きくなった場合には全ての実測される状態量に対してモデルパラメータの学習を試みる。すなわち、補助変数としてｉを1に設定し、ｉ番目の状態量に関する偏差とｉ番目以外の全ての実測できる状態量1つ1つとの相関を解析する。解析した結果、ｉ番目の状態量と相関係数の高い他の状態量を選択する。具体的には、図8に示す炉水^{60}Ｃｏ濃度に対する偏差δ_iと他の状態量であるｐＨとの相関を取った時、図9に示すような負の強い相関が得られたとすると、ｐＨを相関の高い状態量として選択することになる。次に、ｉ番目の状態量の解析結果に大きく影響するモデルパラメータを選択して、そのモデルパラメータ

を算出する式に前記選択した状態量の寄与項を加える。図８、図９の例の場合は、炉水^{60}Ｃｏ濃度に大きく影響するモデルパラメータとしては、燃料棒からの溶出速度ζを選択し、ζを算出する式にｐＨの項を追加する。つまり、追加前のζが$\zeta = a$（定数）として定義されていたとき、$\zeta = a + b \cdot z$（ただし、ｚはｐＨの値、ｂは比例係数）というようにｐＨの寄与項を加える。このようにして、モデルパラメータ算出式を変更したシミュレーションプログラムの暫定版を作成してコンパイル後実行する。解析結果から偏差二乗和を算出して偏差二乗和が縮小すれば、暫定版を改善版として採用し、比例係数をパラメータとして最小の偏差二乗和を与える値をパラメータサーベイから決定する。縮小しない場合は追加項の比例係数を変更して再度暫定版を作成して調べる。比例係数を大小両方向に変更しても偏差二乗和が縮小しなければ、モデルパラメータの選択またはｉ番目の状態量に対する相関が小さかったとして暫定版を廃棄して、次のステップに進む。ｉを１つ増加させて同様の処理を行ない、全ての状態量に対する処理が完了したところで自己学習プロセスが終了する。本実施例によれば、シミュレーションモデルのモデルパラメータの最適化並びにモデルの自己学習による高度化の作業が計算機により自動的に行なわれるので、労力が大幅に低減されると共に、全てのパラメータ、状態量に関する相関を調べるので、調査もれが無くなり、信頼性が向上する。

【００１２】以上説明した実施例では、１つのプラントデータに基づきシミュレーションモデルの自己学習を行なっていたが、図１０に示すように複数のプラント９のデータを多プラントデータベース２０を介して、プラントの自己学習診断、予測装置１に取り込むことにより、学習の幅を広げることができる。すなわち、１つのプラントでは変化の小さい状態量も複数のプラントでは幅を持つこともあるので、このような場合では複数のプラントでそれぞれ最適化されたモデルパラメータと前記の状態量との相関を解析することにより、図１１に示すような相関関係を得る可能性がある。このように複数のプラントデータを用いて自己学習することにより、モデルの汎用性が増し、新規プラントへの適用性が向上する。

【００１３】また、図１にプラントの自己学習診断、予測装置の装置構成を示したが、実際上は通常の計算機システムとして大部分が実現可能であり、自己学習診断、予測の各機能はソフトウェア的に実現できる。本発明の実施例を実現するためには、図１２に示すように上位にプラントの自己学習診断、予測用のソフトウェアを設け、シミュレーション用のソフトウェアを下位に位置付ける構成とし、上位ソフトウェアからシミュレーションソフトウェアのプログラムのソースを修正、コンパイル、実行制御して達成する。また、計算機システムとしては単独のプロセッサを持つものでも実現できるが、図１３に示すようにシミュレーション専用計算機を用いたシステムとすることもできる。このようにシミュレーション専用計算機を用いると大型シミュレーションを別の計算機で高速に実行させることも可能となり、システムとしての応答性が向上する。特に、図１４に示すように複数のシミュレーション専用計算機を用いたシステムではパラメータサーベイ機能を並行的に実施可能となり、モデルパラメータの最適化及びモデルの自己学習時間を大幅に短縮することができる。

【００１４】

【発明の効果】本発明により、実プラントの測定データに基づきシミュレーションモデルのモデルパラメータの自己修繕、並びにモデルの自己学習による改善が可能となるので、診断、予測精度が向上すると共に、シミュレーションモデルのメインテナンスに関わる労力の削減が可能となり、ひいてはプラントの信頼性、経済性向上の効果がある。

【図面の簡単な説明】

【図１】本発明のプラントの自己学習診断、予測装置の構成と原子力発電プラントへの適用例を示す。

【図２】モデルパラメータ最適化部の構成を示す。

【図３】原子炉一次系腐食生成物のマスバランスモデルを示す。

【図４】自己学習診断、予測方法の手順を示す。

【図５】異常診断と波及事象の予測の詳細手順を示す。

【図６】モデルパラメータ最適化の詳細手順を示す。

【図７】自己学習の詳細手順を示す。

【図８】モデルパラメータを最適化を実施した例を示す。

【図９】実測パラメータと偏差の相関解析を実施した例を示す。

【図１０】多プラントデータを用いた自己学習診断、予測装置構成を示す。

【図１１】多プラントデータに基づく相関解析を実施した例を示す。

【図１２】プラントの自己学習診断、予測装置のソフトウェア構成を示す。

【図１３】プラントの自己学習診断、予測装置を構成する計算機システム構成の１つを示す。

【図１４】プラントの自己学習診断、予測装置を構成する別の計算機システム構成の１つを示す。

【図１５】偏差パターンの定義例（表１）

【図１６】異常検出時の偏差パターン表の例（表２）

【図１７】変化パターン表の例（表３）

【図１８】変化パターンの定義例（表４）

【図１９】差分パターンの定義例（表５）

【図２０】改善度スコアの定義例（表６）

【図２１】改善度スコア作成例（表７）

【符号の説明】

1　プラントの自己学習診断、予測装置
2　プラントの自己学習診断、予測制御部

3　モデルパラメータ最適化部
4　相関解析部
5　自己学習部
6　異常検出部
7　予測部
8　診断予測結果表示部
9　原子力発電プラント
10　プロセスコンピュータ
11　各種計測器
＊12　モデルパラメータ最適化制御部
13　プラントパラメータ設定部
14　標準パラメータ設定部
15　モデルパラメータ収納部
16　解析入力収納部
17　シミュレーション実行部
18　解析結果収納部
19　変化パターン作成部
＊　20　多プラントデータベース

【図1】

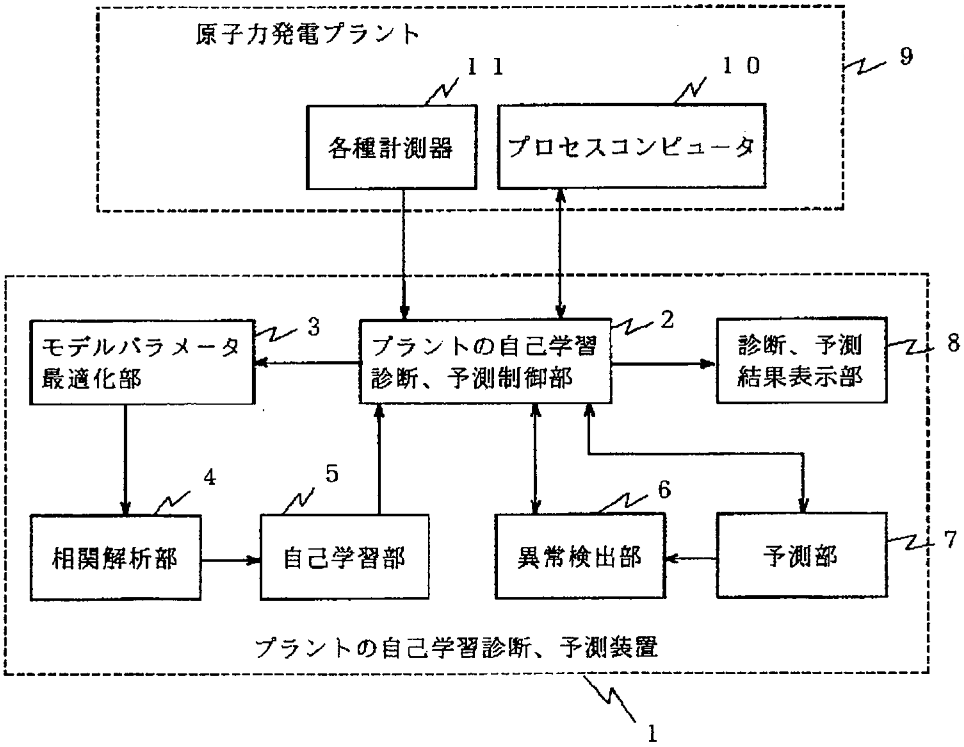
プラントの自己学習診断、予測装置の構成と原子力プラントへの適用例（図１）

【図9】

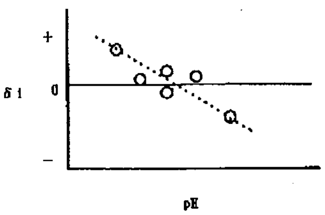
相関解析実施例（図９）

【図3】

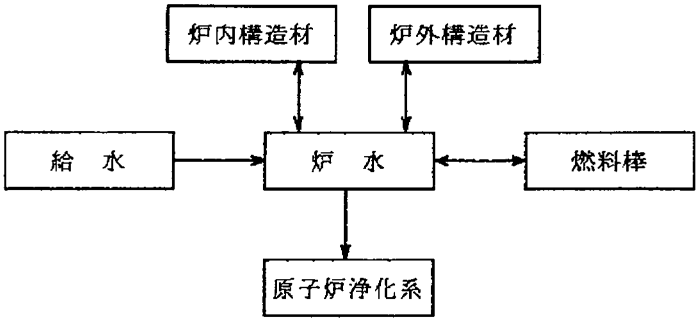
原子炉一次系腐食生成物のマスバランスモデル（図３）

【図11】

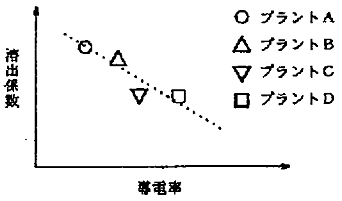
多プラントデータに基づく相関解析実施例（図１１）

【図２】

モデルパラメータ最適化部の構成（図２）

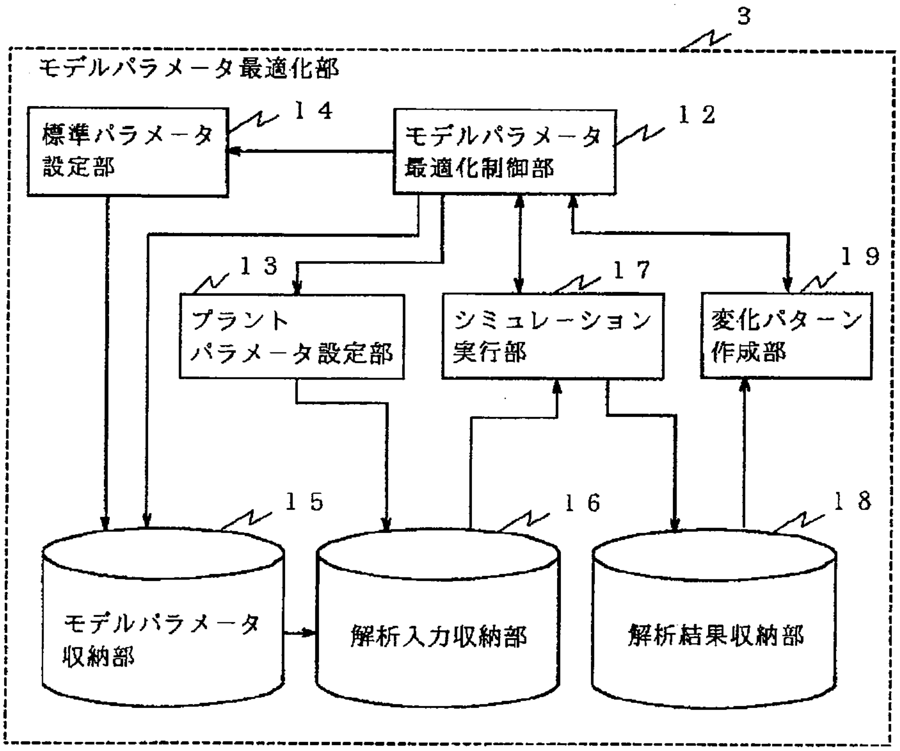

【図５】

診断の手順（図５）

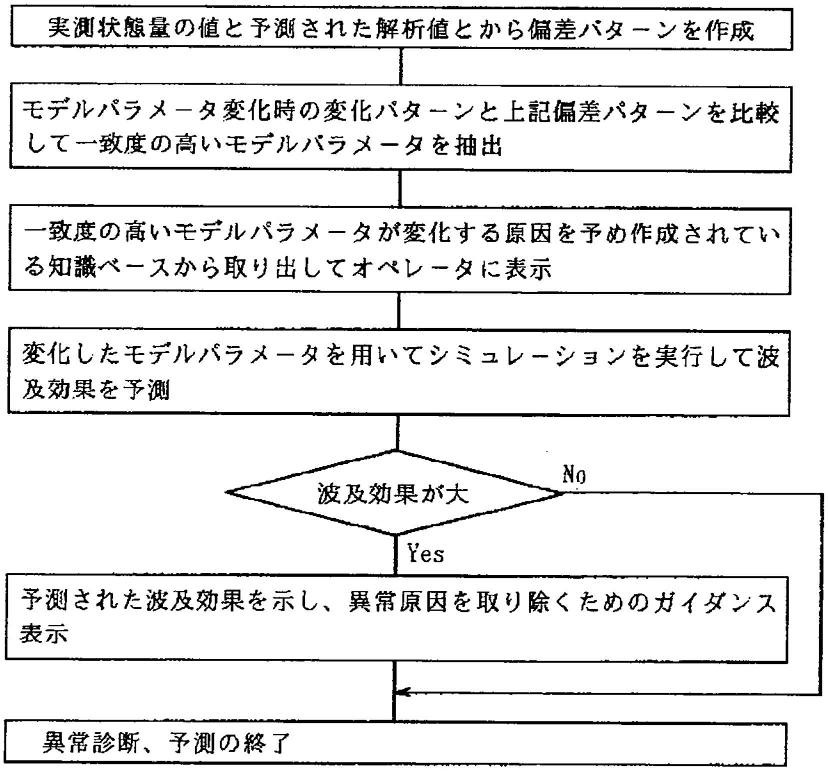
実測状態量の値と予測された解析値とから偏差パターンを作成
モデルパラメータ変化時の変化パターンと上記偏差パターンを比較して一致度の高いモデルパラメータを抽出
一致度の高いモデルパラメータが変化する原因を予め作成されている知識ベースから取り出してオペレータに表示
変化したモデルパラメータを用いてシミュレーションを実行して波及効果を予測
波及効果が大
No
Yes
予測された波及効果を示し、異常原因を取り除くためのガイダンス表示
異常診断、予測の終了

【図4】

自己学習診断、予測方法の手順（図４）

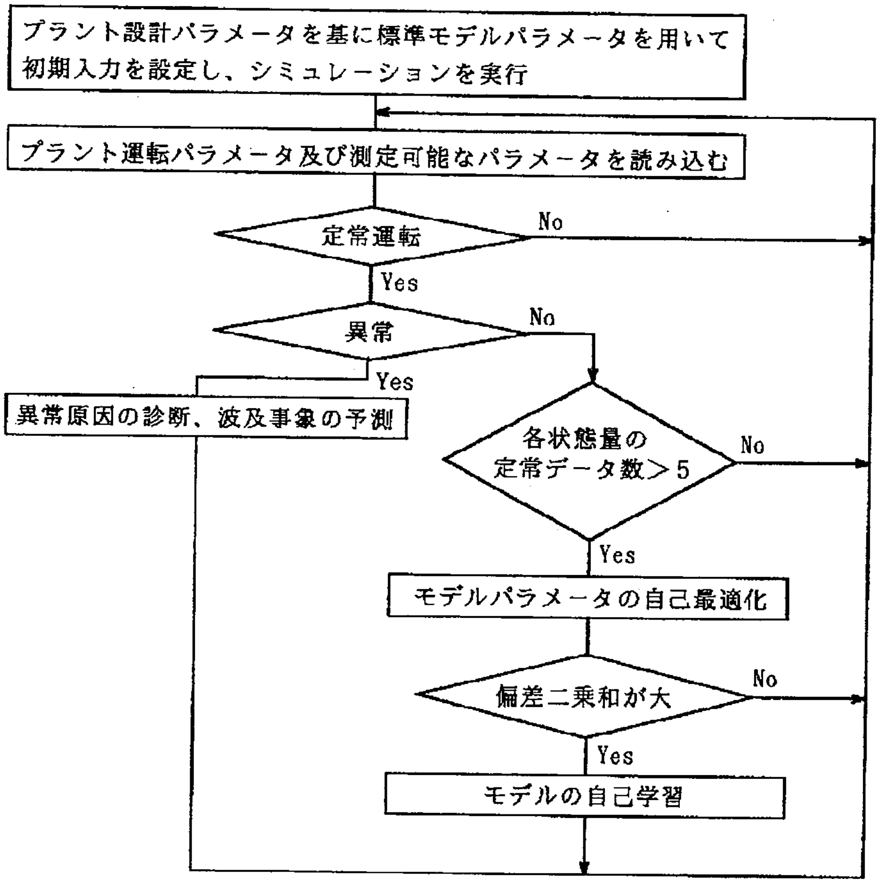
プラント設計パラメータを基に標準モデルパラメータを用いて初期入力を設定し、シミュレーションを実行
プラント運転パラメータ及び測定可能なパラメータを読み込む
定常運転
No
Yes
異常
No
Yes
異常原因の診断、波及事象の予測
各状態量の定常データ数＞5
No
Yes
モデルパラメータの自己最適化
偏差二乗和が大
No
Yes
モデルの自己学習

【図8】

モデルパラメータ最適化実施例図（図８）

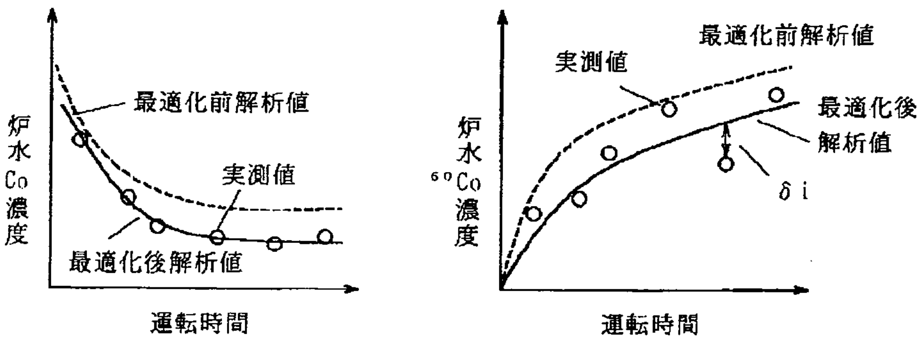

【図12】

ソフトウェア構成図（図１２）

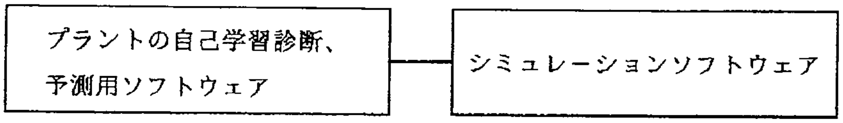
プラントの自己学習診断、予測用ソフトウェア
シミュレーションソフトウェア

【図6】

モデルパラメータ最適化手順（図６）

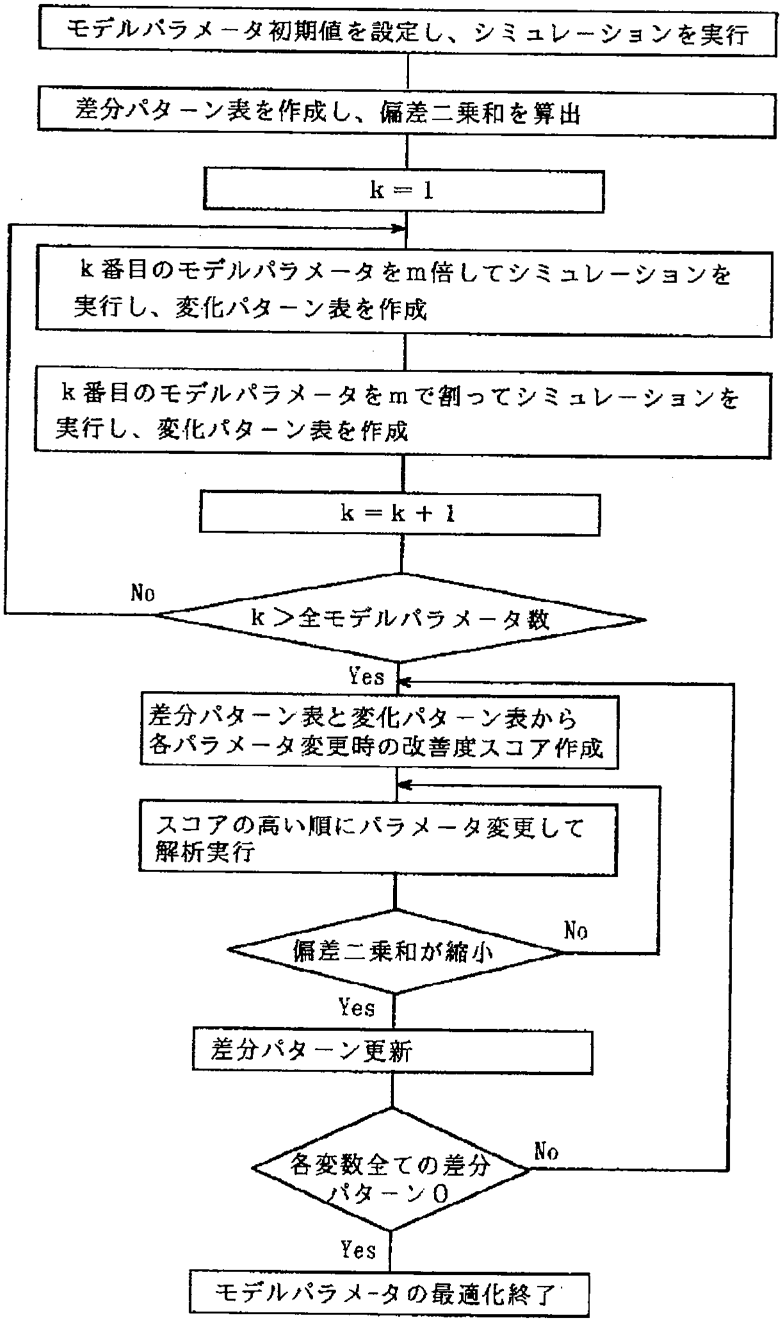
モデルパラメータ初期値を設定し、シミュレーションを実行
差分パターン表を作成し、偏差二乗和を算出
k＝1
k番目のモデルパラメータをm倍してシミュレーションを実行し、変化パターン表を作成
k番目のモデルパラメータをmで割ってシミュレーションを実行し、変化パターン表を作成
k＝k＋1
No
k＞全モデルパラメータ数
Yes
差分パターン表と変化パターン表から各パラメータ変更時の改善度スコア作成
スコアの高い順にパラメータ変更して解析実行
No
偏差二乗和が縮小
Yes
差分パターン更新
No
各変数全ての差分パターン０
Yes
モデルパラメータの最適化終了

【図１３】

計算機システム構成例１（図１３）

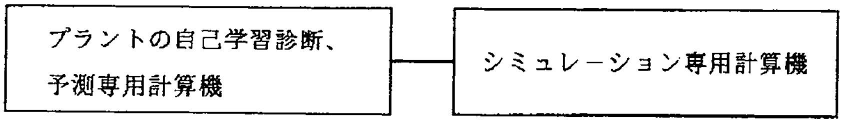
プラントの自己学習診断、予測専用計算機
シミュレーション専用計算機

【図７】

自己学習の手順（図７）

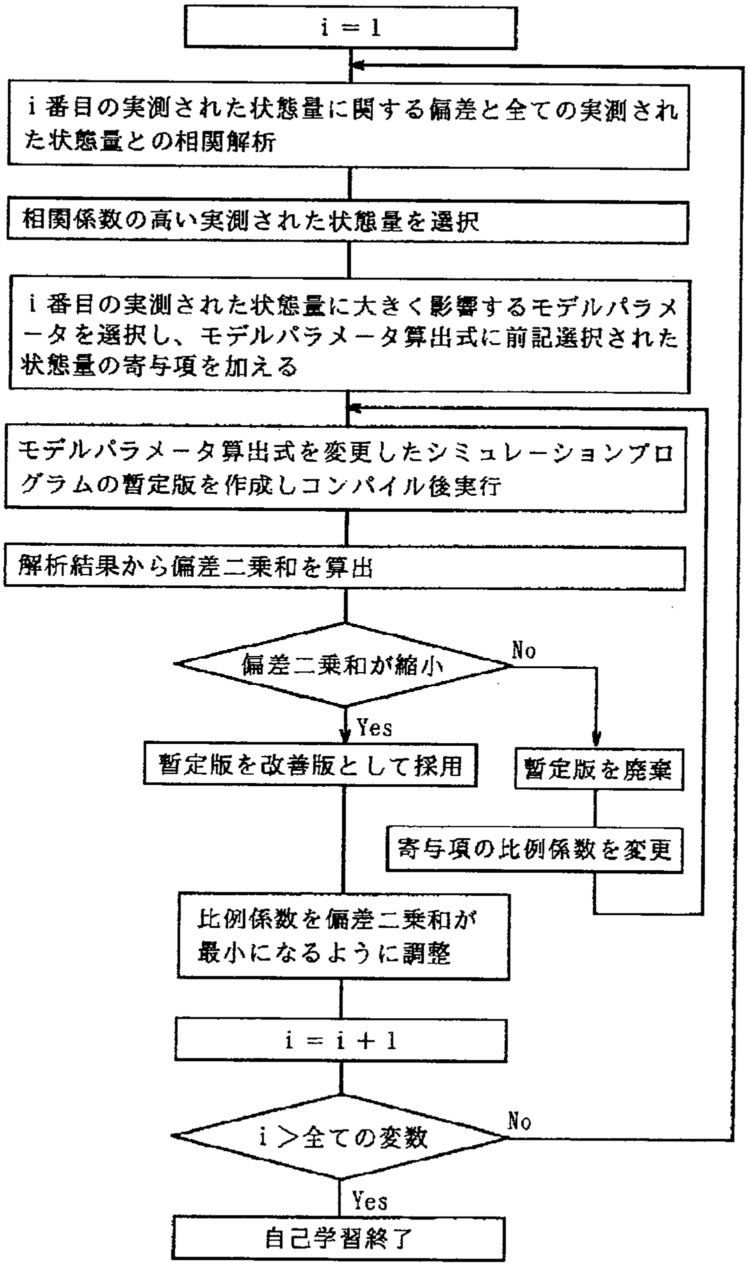
ｉ＝１
ｉ番目の実測された状態量に関する偏差と全ての実測された状態量との相関解析
相関係数の高い実測された状態量を選択
ｉ番目の実測された状態量に大きく影響するモデルパラメータを選択し、モデルパラメータ算出式に前記選択された状態量の寄与項を加える
モデルパラメータ算出式を変更したシミュレーションプログラムの暫定版を作成しコンパイル後実行
解析結果から偏差二乗和を算出
偏差二乗和が縮小
No
Yes
暫定版を改善版として採用
暫定版を廃棄
寄与項の比例係数を変更
比例係数を偏差二乗和が最小になるように調整
ｉ＝ｉ＋１
ｉ＞全ての変数
No
Yes
自己学習終了

【図１５】

偏差パターンの定義例（表１）（図１５）

$v_i／y_i$	＞２	＞1.5	＜0.67	＜0.5	＜０	0.67≦，≦1.5
パターン	＋＋	＋	－	－－	＋－	０

ただし、y_iはｉ番目の測定可能な状態量の解析値
v_iはｉ番目の測定可能な状態量の実測値

【図１０】

多プラントデータを用いた学習診断、予測装置構成図（図１０）

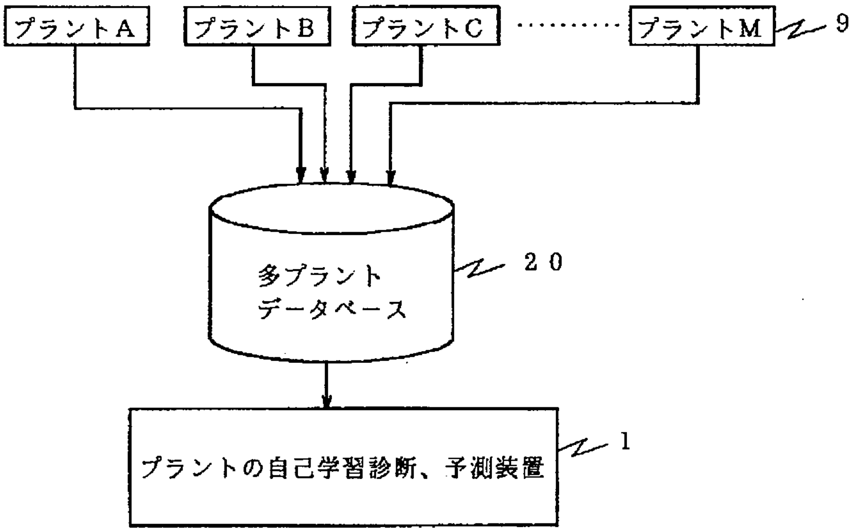

【図１４】

計算機システム構成例２（図１４）

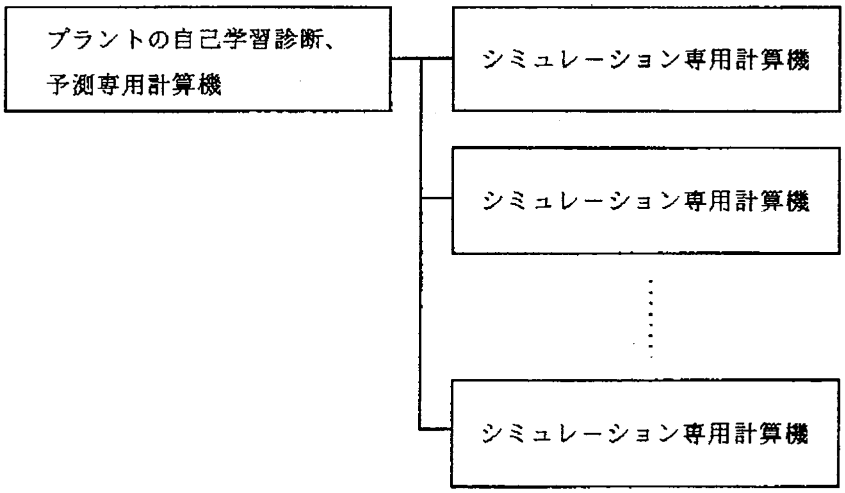
プラントの自己学習診断、
予測専用計算機
シミュレーション専用計算機
シミュレーション専用計算機
シミュレーション専用計算機

【図１６】

異常検出時の偏差パターン表の例（表２）（図１６）

状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
パターン	0	＋	0	0	0	0	＋	0	0	0

【図１７】

変化パターン表の例（表３）（図１７）

・炉内ステンレス腐食増加

状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
パターン	0	0	0	＋	0	0	0	0	＋	0

・炉内インコネル腐食増加

状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
パターン	0	＋	0	0	0	0	＋	0	0	0

・炉内ステライト腐食増加

状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
パターン	0	0	＋	0	0	0	0	＋	0	0

・給水鉄濃度増加

状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
パターン	＋	0	0	0	0	0	0	0	0	0

・給水ニッケル濃度増加

状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
パターン	0	＋	0	0	0	0	0	0	0	0

・給水コバルト濃度増加

状態量	Fe	Ni	Co	Cr	Na	^{54}Mn	^{58}Co	^{60}Co	^{51}Cr	^{24}Na
パターン	0	0	＋	0	0	0	0	0	0	0

・給水クロム濃度増加

……………

【図１８】

変化パターンの定義例（表４）（図１８）

Y_i/Y_i^*	＞１０	＞2	＜0.5	＜0.1	＜０	0.5≦，≦２
パターン	＋＋	＋	－	－－	＋－	0

ただし、Y_i^*はｉ番目の測定可能な状態量の前回解析値の総和

【図１９】

差分パターンの定義例（表５）（図１９）

Y_i/V_i	＞１０	＞2	＜0.5	＜0.1	＜０	0.5≦，≦２
パターン	＋＋	＋	－	－－	＋－	0

ただし、Y_iはｉ番目の測定可能な状態量の解析値の総和
V_iはｉ番目の測定可能な状態量の実測値の総和

【図２１】

改善度スコア作成例（表７）（図２１）

パラメータ	α_1	α_2	α_3	α_4	α_5	合計
差分パターン	＋＋	＋	－	－	0	
変化パターン	－－	0	＋	＋＋	＋	
スコア	２０	0	1	0	－10	１１

【図２０】

改善度スコアの定義例（表６）（図２０）

Y_i / V_i	＋－	＋－	＋－	＋－	＋－	＋－
Y_i / Y_i^*	＋－	＋＋	＋	－	－－	0
スコア	５０	0	0	0	0	0

Y_i / V_i	＋＋	＋＋	＋＋	＋＋	＋＋	＋＋
Y_i / Y_i^*	－－	－	0	＋	＋＋	＋－
スコア	２０	5	0	－５	－40	－50

Y_i / V_i	＋	＋	＋	＋	＋	＋
Y_i / Y_i^*	－－	－	0	＋	＋＋	＋－
スコア	0	1	0	－５	－20	－50

Y_i / V_i	－	－	－	－	－	－
Y_i / Y_i^*	－－	－	0	＋	＋＋	＋－
スコア	－20	－５	0	1	0	－50

Y_i / V_i	－－	－－	－－	－－	－－	－－
Y_i / Y_i^*	－－	－	0	＋	＋＋	＋－
スコア	－40	－５	0	5	２０	－50

Y_i / V_i	0	0	0	0	0	0
Y_i / Y_i^*	－－	－	0	＋	＋＋	＋－
スコア	－20	－10	0	－10	－20	－50

フロントページの続き

(51) Int. Cl.^{5}	識別記号	庁内整理番号	F I	技術表示箇所
// G05B　23/00	R	7618－3H		

(72)発明者　内田　俊介
茨城県日立市大みか町七丁目２番１号　株式会社日立製作所エネルギー研究所内

(72)発明者　有田　節男
茨城県日立市大みか町七丁目２番１号　株式会社日立製作所エネルギー研究所内

(72)発明者　福崎　孝治
茨城県日立市大みか町七丁目２番１号　株式会社日立製作所エネルギー研究所内

(72)発明者　高橋　文信
茨城県日立市大みか町七丁目２番１号　株式会社日立製作所エネルギー研究所内